

Dr. sc. Anita Čeh Časni

Docentica
Ekonomski fakultet Zagreb
Katedra za statistiku
E-mail: aceh@efzg.hr

Josipa Filić, mag. oec.

Asistentica
Ekonomski fakultet Zagreb
Katedra za statistiku
E-mail: jfilić@net.efzg.hr

MODELIRANJE UTJECAJA NOVČANOG TOKA NA ZADUŽENOST PODUZEĆA U REPUBLICI HRVATSKOJ MODELOM LINEARNE REGRESIJE

UDK / UDC: 658.14/.15

JEL klasifikacija / JEL classification: C30, G30, G32, L25

Preliminary communication / Prethodno priopćenje

Primljeno / Received: September 28, 2019 / 28. rujna 2019.

Prihvaćeno za tisak / Accepted for publishing: December 4, 2019 / 4. prosinca 2019.

Sažetak

Cilj je ovog rada ispitati statističku povezanost novčanog toka i zaduženosti poduzeća korištenjem modelom višestruke linearne regresije. Osim novčanog toka, kao dodatna eksplanatorna varijabla u modelu koristila se i veličina poduzeća. Budući da u relevantnoj literaturi postoje mnoga istraživanja o povezanosti dobiti i zaduženosti, u ovom se radu koristio novčani tok umjesto profita pa je to ujedno i doprinos rada postojećoj literaturi. Rezultati regresijske analize ukazuju na negativan utjecaj novčanog toka na zaduženost, što potvrđuje teoriju redoslijeda pakiranja. Također, rezultati pokazuju pozitivan (iako slabiji) utjecaj veličine poduzeća na zaduženost.

Ključne riječi: model višestruke linearne regresije, novčani tok, zaduženost, veličina poduzeća.

1. UVOD

Dinamično okruženje i stalne promjene zahtijevaju od poduzeća razvoj i unapređivanje proizvoda i usluga. Iz tog razloga javljaju se ulaganja koja je potrebno financirati. Stoga je vrlo važno dobro upravljanje izvorima financiranja.

Budući da je cilj poduzeća osiguravanje dostatnih novčanih sredstava za poslovanje, poduzeća odlučuju hoće li se u većoj mjeri koristiti vlastitim ili, pak, tuđim izvorima sredstava. Stoga se ovim radom želi ispitati utječe li uspješnost poslovanja poduzeća na odluku o zaduživanju. S obzirom na to da neto dobit predstavlja obračunsku osnovu, u ovome će se radu kao nezavisna varijabla koristiti novčani tok kao bolja mjera uspješnosti, što predstavlja doprinos postojećim istraživanjima iz ovoga područja. Nadalje, takvim se doprinosom može smatrati i korištenje pokazateljem na temelju izvještaja o novčanim tokovima u modelu linearne regresije s obzirom na to da se u dosadašnjim istraživanjima koristilo čistim novčanim tokom. Također, prethodna istraživanja o navedenoj temi provedena su na uzorku poduzeća izvan Republike Hrvatske. Stoga je potrebno ispitati kakav je utjecaj novčanog toka na zaduženost poduzeća u Republici Hrvatskoj. Empirijska analiza bit će provedena upotrebom zadnjih dostupnih podataka iz 2018. godine.

Izvještaj o novčanom toku sadrži informacije o novčanim primicima i izdacima u toku obračunskog razdoblja te stanju novca i novčanih ekvivalenata na početku i na kraju obračunskog razdoblja (Gulin & Perčević, 2013). Također, izvještaj o novčanom toku pruža uvid u promjene u strukturi imovine, obveza i kapitala. Na temelju izvještaja o novčanom toku mogu se izračunati različiti pokazatelji. Oni se mogu svrstati u četiri skupine: pokazatelji likvidnosti, pokazatelji kvalitete dobiti, pokazatelji kapitalnih izdataka te pokazatelji povrata novčanog toka. U ovom istraživanju koristit će se pokazatelj novčanog pokrivača ukupnih obveza koji pripada skupini pokazatelja likvidnosti.

Razlog zbog kojeg će se koristiti pokazatelj na temelju izvještaja o novčanom toku, a ne na temelju računa dobiti i gubitka jest u tome što se želi ispitati utjecaj novčanog toka kao novčane osnove na zaduženost jer neto dobit prikazuje obračunsku osnovu. Dakle, u ovom se istraživanju smatra da izvještaj o novčanom toku sadrži relevantnije podatke o uspješnosti poduzeća u usporedbi s računom dobiti i gubitka, što će se i empirijski dokazati.

Struktura je rada sljedeća: nakon uvodnog dijela slijedi pregled relevantne literature. U trećem se dijelu opisuje metodologija istraživanja. U četvrtom se dijelu iznose podaci i rezultati empirijskog istraživanja, dok se u petom i zadnjem dijelu rada donose zaključna razmatranja.

2. PREGLED LITERATURE

Važnost izvještaja o novčanim tokovima naglašavaju i brojni autori u svojim istraživanjima. Giacomino & Mielke (1993) te Gurtani & Mehr (2015) ukazuju na važnost informacija dobivenih iz izvještaja o novčanom toku. Također, prema istraživanju koje su 2018. godine proveli Hladika, Valenta & Milčić, važnost se novca ogleda u činjenici da se njime, a ne ostvarenom dobiti, kupuje imovina te isplaćuju plaće, plaćaju usluge i ostale obveze prema dobavljačima i kreditorima te plaćaju porezi.

Ispitivanje povezanosti novčanog toka i zaduženosti tema je o kojoj su provedena brojna istraživanja. Naime, zaduženost je povezana s izvorima financiranja, odnosno strukturom kapitala. Postoje poduzeća koja se u većoj mjeri koriste tuđim sredstvima za potrebe financiranja, kao i ona koja se koriste vlastitim. Stoga se postavlja pitanje ovisi li stupanj zaduženosti o uspješnosti, kao i o veličini poduzeća. Ando, Matsumoto & Matsumoto (2017) u svom istraživanju ukazuju na to da financiranje zaduživanjem utječe na smanjenje rasta i stabilnosti. Tong & Green (2005) na uzorku kineskih poduzeća potvrđuju postojanje negativnog odnosa između dobiti i zaduženosti poduzeća. Hall, Hutchinson & Michaelas (2004) te Booth, Aivazian, Demircuc-Kunt & Maksimović (2001) ukazuju na negativnu povezanost između zaduženosti i profitabilnosti. Međutim, profitabilnost je prikazana pomoću pokazatelja koji se temelje na računu dobiti i gubitka, a ne na izvještaju o novčanim tokovima, kao što je to u ovome radu te u istraživanjima određenih autora. Alnawaiseh, Alomari, Al-Rawashdeh & Alnawaiseh (2017) u svome istraživanju koristili su se slobodnim novčanim tokom kao nezavisnom varijablom. Na uzorku poduzeća iz Jordana došli su do zaključka o negativnoj povezanosti između slobodnog novčanog toka i zaduženosti. Matemilola, Nassir & Bany-Arifin (2014) u svom istraživanju na uzorku poduzeća iz Južne Afrike dolaze do zaključka o negativnoj povezanosti između novčanog toka i zaduženosti. To se povezuje s jednom od teorija strukture kapitala, a to je teorija redoslijeda pakiranja (engl. *pecking-order theory*). Matemilola, Kareem, Mautin & Sakiru (2015) ispitali su navedenu teoriju strukture kapitala na temelju povezanosti zaduženosti i novčanog toka te uočili negativnu povezanost između navedenih varijabli. Autori su teorije redoslijeda pakiranja Myers & Majluf (1984), koji u svojoj teoriji naglašavaju informacijsku asimetriju koja se javlja između vlasnika i menadžera u poslovanju poduzeća. Rezaei & Jafari (2015) u svom su istraživanju na uzorku poduzeća koja kotiraju na Teheranskoj burzi došli do zaključka o negativnoj povezanosti između novčanog toka i pokazatelja zaduženosti. Stoga su rezultati ovog istraživanja na uzorku poduzeća iz Republike Hrvatske u skladu s rezultatima prethodno spomenutih autora. Međutim, postoje razlike u korištenim varijablama u modelu. Rezaei & Jafari (2015) koriste se novčanim tokovima poduzeća, dok se u ovome empirijskom istraživanju koristi pokazatelj na temelju izvještaja o novčanom toku. Također, stavlja se naglasak na novčanim tokovima iz poslovnih aktivnosti jer oni čine najvažniji i najveći dio novčanih tokova u poslovanju te je iz navedenog razloga izabran pokazatelj novčanog pokrića ukupnih obveza kao nezavisna varijabla u modelu. U nastavku rada opisuje se korištena metodologija.

3. METODOLOGIJA ISTRAŽIVANJA

U ovome radu za ispitivanje statističke povezanosti između zaduženosti poduzeća, novčanog toka i veličine poduzeća koristit će se model višestruke linearne regresije. Njime se ispituje ovisnost jedne zavisne varijable o više nezavisnih varijabli. Buse, Ganea & Cîrciumaru (2010) smatraju da se sve više analitičara koristi višestrukom linearnom regresijom jer je danas olakšan pristup

velikom broju financijskih i nefinancijskih informacija. Model višestruke linearne regresije omogućuje bogatiju empirijsku analizu jer uključuje više čimbenika koji imaju utjecaj na određenu pojavu.

Odnos između varijabli može biti nelinearan te je stoga potrebno pojasniti način na koji se model koji nije linearan može linearizirati. U ovome radu koriste se logaritmirane vrijednosti ukupne imovine za svako poduzeće iz uzorka. Budući da sve varijable nisu logaritmirane, model naveden u izrazu 1 predstavlja polulogaritamski model (*lin-log*)

$$y = \beta_0 + \beta_1 \ln(x_1) + \dots + \beta_k \ln(x_k) + \varepsilon \quad (1)$$

U modelu višestruke linearne regresije, za ispitivanje značajnosti svih varijabli koristi se *F*-test, čije su hipoteze dane u izrazu (2):

$$\begin{aligned} H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0 \\ H_1 : \exists \beta_j \neq 0, j = 1, 2, \dots, k \end{aligned} \quad (2)$$

Nultom se hipotezom pretpostavlja da niti jedna regresorska varijabla nije značajna u modelu. S druge strane, alternativnom hipotezom pretpostavlja se da je barem jedna varijabla značajna u modelu te da statistički značajno objašnjava varijacije u zavisnoj varijabli *y*.

$$F = \frac{\frac{SP}{k}}{\frac{SR}{n-(k+1)}} \quad (3)$$

Odluka o ishodu testa donosi se na temelju usporedbe testne veličine *F* i teorijske vrijednosti *F* distribucije s (*k*, *n* - (*k* + 1)) stupnjeva slobode. Odluka o ishodu testa donosi se na uobičajen način; uz razinu značajnosti α , H_0 ne može se prihvatiti ako je empirijski *F* – omjer veći od kritične vrijednosti $F_{(k, n-(k+1))}^\alpha$.

Ono što je važno napomenuti kada se analizira model višestruke linearne regresije jest pretpostavka da regresorske varijable nisu korelirane i da niti jedna varijabla nije konstanta. U slučaju narušavanja navedene pretpostavke dolazi do problema multikolinearnosti. Savršena multikolinearnost javlja se kada su dvije ili više regresorskih varijabli linearno zavisne, dok se problem približne multikolinearnosti ili približne linearne zavisnosti regresorskih varijabli javlja u slučaju ako su dvije ili više regresorskih varijabli visoko korelirane (Dumičić, i dr., 2011).

Najčešće su korištene metode u otkrivanju problema multikolinearnosti faktor inflacije varijance *VIF* ili ekvivalentni pokazatelj *TOL* te kondicijski broj *CN* i kondicijski indeks *CI*. Faktor inflacije varijance i *TOL* pokazatelji definirani su sljedećim izrazima:

$$VIF_j = \frac{1}{1-R_j^2}, TOL_j = \frac{1}{VIF_j} = 1 - R_j^2, j = 1, 2, \dots, k \quad (4)$$

Ako postoji jaka linearna povezanost između varijable x_j i preostalih regresorskih varijabli, koeficijent determinacije R_j^2 bit će približno jednak jedan, vrijednost VIF_j pokazatelja vrlo velika, a vrijednost TOL_j približno jednaka nuli.

Još jedan od pokazatelja multikolinearnosti jest kondicijski indeks CI . Navedeni pokazatelj mjeri osjetljivost procjena na male promjene u podacima. Kondicijski indeks CI predstavlja drugi korijen omjera najveće svojstvene vrijednosti i odabrane svojstvene vrijednosti λ_i te je definiran izrazom:

$$CI_i = \sqrt{\frac{\lambda_{max}}{\lambda_i}}, \quad i = 1, 2, \dots, k \quad (5)$$

Ovdje se primjenjuje praktično pravilo te vrijednosti veće od 15 ukazuju na mogući problem multikolinearnosti, dok vrijednosti navedenih pokazatelja veće od 30 ukazuju na ozbiljan problem multikolinearnosti. Multikolinearnost je česta pojava u regresijskim modelima te se može umanjiti povećanjem broja podataka, čime se dobivaju preciznije procjene.

Problem autokorelacije grešaka relacije javlja se u slučaju da je pretpostavka kako greške relacije nisu korelirane narušena. Jedan od najčešće korištenih načina ispitivanja autokorelacije grešaka relacije provodi se Durbin–Watsonovim testom. Ako postoji autokorelacija prvog reda, odnosno ako su uzastopni članovi grešaka relacije korelirani, tada vrijedi:

$$\varepsilon_t = \rho_1 \varepsilon_{t-1} + u_t \quad (6)$$

Parametar ρ_1 u navedenoj jednadžbi jest koeficijent korelacije između „susjednih“ članova grešaka relacije ε_{t-1} i ε_t .

Testna veličina DW -testa definirana je izrazom:

$$DW = \frac{\sum_{t=2}^n (\hat{\varepsilon}_t - \hat{\varepsilon}_{t-1})^2}{\sum_{t=1}^n \hat{\varepsilon}_t^2} \quad (7)$$

Kada autokorelacija ne postoji, vrijedi da je $\rho_1 = 0$ i $DW \approx 2$. Ako se radi o jakoj pozitivnoj autokorelaciji, tada je $\rho_1 \approx 1$ i $DW \approx 0$, dok pri jakoj negativnoj autokorelaciji vrijedi: $\rho_1 \approx -1$ i $DW \approx 4$.

Jednosmjerni test o pozitivnoj autokorelaciji u pravilu se provodi kada je $0 \leq DW \leq 2$. Usporedbom testne veličine s tabličnim kritičnim vrijednostima d_L i d_U donosi se odluka o ishodu testa. Kada je $DW < d_L$, nulta se hipoteza odbacuje i zaključuje se da su greške relacije pozitivno autokorelirane. Ako je $DW > d_U$, nulta hipoteza ne odbacuje se i zaključuje se da nema autokorelacije grešaka relacije. U slučaju $d_L < DW < d_U$ ne može se donijeti odluka na temelju DW -testa.

Jednosmjerni test o negativnoj autokorelaciji u pravilu se provodi ako je $2 \leq DW \leq 4$. Odluka se donosi na temelju usporedbe testne veličine s kritičnim vrijednostima $4 - d_U$ i $4 - d_L$. Ako je $DW > 4 - d_L$, nulta hipoteza može se odbaciti i zaključuje se da su greške relacije negativno autokorelirane. U slučaju da je $DW < 4 - d_U$, nulta hipoteza ne može se odbaciti i zaključuje se da nema

autokorelacije grešaka relacije. U slučaju $4 - d_U < DW < 4 - d_L$ ne može se donijeti odluka na temelju DW -testa, odnosno test je inkonzluzivan.

Najčešći razlog zbog kojeg se javlja problem autokorelacije grešaka relacije jest neuključivanje dodatnih značajnih sistematskih faktora koji utječu na zavisnu varijablu. Problem autokorelacije grešaka relacije, kao i problem multikolinearnosti ispitat će se u sljedećem dijelu rada, gdje će se prikazati i rezultati provedenog empirijskog istraživanja.

4. REZULTATI EMPIRIJSKE ANALIZE

Ispitivanje povezanosti između novčanog toka i zaduženosti provedeno je modelom višestruke linearne regresije, pri čemu je u model, kao dodatna eksplanatorna varijabla, uključena veličina poduzeća. Empirijsko istraživanje provedeno je na uzorku 47 poduzeća koja kotiraju na Zagrebačkoj burzi i za koja su bili dostupni podaci na stranicama Registra godišnjih financijskih izvještaja, a prikazani su u Tablici 1.

Tablica 1.

Uzorak poduzeća za empirijsku analizu

	Naziv poduzeća
1.	AD PLASTIK
2.	AGROMEĐIMURJE
3.	BADEL 1862
4.	BRODOMERKUR
5.	CROATIA AIRLINES
6.	ČATEKS
7.	DALEKOVOD
8.	DRVNA INDUSTRIJA SPAČVA
9.	DUKAT
10.	ERICSSON NIKOLA TESLA
11.	GRANOLIO
12.	HOTELI BRELA
13.	HOTELI JADRAN
14.	HOTELI MAESTRAL
15.	HOTELI TUCEPI
16.	HOTELI ZIVOGOSCE
17.	HTP KORČULA
18.	HTP OREBIĆ
19.	JADROAGENT
20.	JELSA
21.	KOESTLIN
22.	KOKA
23.	KONCAR DISTRIBUTIVNI I SPECIJALNI TRANSFORMATORI
24.	KOTEKS
25.	KRAŠ
26.	KUTJEVO
27.	LIBURNIA RIVIERA HOTELI
28.	LUKA PLOČE
29.	MAISTRA
30.	MARASKA
31.	MEDORA HOTELI I LJETOVALIŠTA
32.	OLYMPIA VODICE
33.	OT-OPTIMA TELEKOM
34.	PALACE HOTEL ZAGREB
35.	PETROKEMIJA
36.	PLAVA LAGUNA
37.	PODRAVKA
38.	SAPONIA
39.	SOLARIS
40.	TANKERSKA NEXT GENERATION
41.	TEKSTILPROMET
42.	TURISTHOTEL
43.	VALAMAR RIVIERA
44.	VIRO TVORNICA ŠEĆERA
45.	VJESNIK
46.	ZAGREBACKE PEKARNE KLARA
47.	ŽITNJAK

Izvor: Registar godišnjih financijskih izvješća, dostupno na: <http://rgfi.fina.hr/JavnaObjava-web/izbornik.do>

Nadalje, u Tablici 2 prikazane su varijable koje su se koristile u modelu višestruke linearne regresije. Koeficijent zaduženosti zavisna je varijabla u modelu te se računa kao omjer ukupnih obveza i ukupne imovine. Koeficijent zaduženosti jedan je od najpoznatijih pokazatelja statičke zaduženosti te ukazuje na to kakva je struktura kapitala, odnosno kakvi su izvori financiranja. Nadalje, novčano pokriva ukupnih obveza kao omjer novčanog toka iz poslovnih aktivnosti i ukupnih obveza predstavlja prvu nezavisnu varijablu.

Tablica 2.

Nazivi i opis varijabli

koefZad	$\text{Koeficijent zaduženosti} = \frac{\text{Ukupne obveze}}{\text{Ukupna imovina}}$
NPUO	$\text{Novčano pokriva ukupnih obveza} = \frac{\text{Novčani tok iz poslovnih aktivnosti}}{\text{Ukupne obveze}}$
imovina	$\text{veličina poduzeća} = \ln \text{ukupna imovina}$

Izvor: Izrada autora.

Druga je nezavisna varijabla veličina poduzeća. Navedena varijabla koristi se u modelu kako bi se ispitalo postoji li statistički značajna razlika u zaduženosti poduzeća ovisno o veličini poduzeća, pri čemu je zamjenska varijabla za veličinu poduzeća ukupna imovina.

Tablica 3.

Rezultati – analiza varijance

Izvor varijacije	Stupnjevi slobode	Zbroj kvadrata	Sredina kvadrata	F-omjer	p-vrijednost
Protumačen modelom	2	0.8521	0.4260	16.64	<.0001
Neprotumačen modelom	44	1.1266	0.0256		
Ukupno	46	1.9787			

Izvor: Izrada autora u statističkom programu SAS.

U Tablici 3. prikazani su rezultati analize varijance. Tablica ANOVA prikazuje analizu varijance, stupnjeve slobode, zbroj kvadrata, sredine kvadrata te vrijednost F -omjera. Odluka prilikom testiranja značajnosti svih varijabli donosi se usporedbom testne veličine i teorijske vrijednosti F distribucije s (2,44) stupnjeva slobode. Dakle, prosječno odstupanje empirijskih vrijednosti koeficijenta zaduženosti od onih regresijskih iznosi 0,16 izraženo apsolutno, odnosno 35,82% izraženo relativno, što prikazuje Tablica 4.

Tablica 4.

Rezultati – standardna devijacija, koeficijent varijacije i koeficijent determinacije

Procjena standardne devijacije	0.1600	Koeficijent determinacije	0.4306
Aritmetička sredina zavisne varijable	0.4467	Korigirani koeficijent determinacije	0.4047
Koeficijent varijacije	35.8239		

Izvor: Izrada autora u statističkom programu SAS.

Također, na temelju rezultata analize može se zaključiti da je modelom protumačeno 43,06% svih odstupanja u modelu.

Tablica 5.

Matrica korelacije

	koefZad	NPUO	Imovina
koefZad	1.0000	-0.5739	0.2294
NPUO	-0.5739	1.0000	0.1484
Imovina	0.2294	0.1484	1.0000

Izvor: Izrada autora u statističkom programu SAS.

Tablica 5. prikazuje korelacijsku matricu koja ukazuje na povezanost između analiziranih varijabli. Koeficijent linearne korelacije između novčanog pokrića ukupnih obveza i koeficijenta zaduženosti iznosi -0,57, što ukazuje na jaku negativnu vezu između navedenih varijabli. Stoga se može zaključiti da novčano pokriće ukupnih obveza ima značajan utjecaj na koeficijent zaduženosti. Koeficijent linearne korelacije između veličine poduzeća i zaduženosti ukazuje na pozitivnu vezu između navedenih varijabli, ali je povezanost slabija u odnosu na prethodno spomenutu.

U sljedećoj tablici prikazani su rezultati dobiveni ispitivanjem povezanosti varijabli modelom višestruke linearne regresije. Također, prikazani su pokazatelji *TOL* i *VIF* kako bi se donijeli zaključci o multikolinearnosti.

Tablica 6.

Rezultati – procjena parametara

Varijabla	Procjena parametra	Standardna pogreška	t-omjer	p-vrijednost	TOL	VIF
Konstantni član	-0.1509	0.2715	-0.56	0.5810		0
NPUO	-0.9764	0.1807	-5.40	<.0001	0.9779	1.0225
Imovina	0.0587	0.0209	2.80	0.0076	0.9779	1.0225

Izvor: Izrada autora u statističkom programu SAS.

Na temelju dobivenih rezultata prikazanih u Tablici 6. može se zapisati regresijska jednačba s procijenjenim parametrima:

$$\hat{y} = -0,1509 - 0,9764x_1 + 0,0587\ln x_2 \quad (8)$$

Kao što je već spomenuto, model u navedenoj jednačbi predstavlja polulogaritamski model s obzirom na to da nisu sve varijable logaritmirane. Regresijski koeficijent $\hat{\beta}_1$ ima negativni predznak te ukazuje da između novčanog toka i zaduženosti postoji negativna povezanost. Ako se novčano pokrće ukupnih obveza poveća za 1%, uz nepromijenjenu imovinu, koeficijent zaduženosti će se u prosjeku smanjiti za 97,64%. Dakle, novčani tok ima značajnu ulogu prilikom donošenja odluke o zaduživanju. Na temelju dobivenih rezultata može se zaključiti da će se poduzeća s većim novčanim tokovima manje zaduživati, što potvrđuju prethodna istraživanja, kao i teorija redoslijeda pakiranja. Regresijski koeficijent $\hat{\beta}_2$ iznosi 0,0587, što ukazuje na to da ako se imovina poduzeća poveća za 1%, uz nepromijenjeno novčano pokrće, koeficijent zaduženosti će se u prosjeku povećati za 5,87%. Pri procjeni parametara vidljivo je da je empirijska razina signifikantnosti (p -vrijednost) ispod razine značajnosti α za obje nezavisne varijable, što znači da su obje nezavisne varijable statistički značajne u modelu.

Nakon procjene parametara, potrebno je ispitati jesu li narušene pretpostavke regresijskog modela. Ispitivanje narušavanja pretpostavki dio je regresijske dijagnostike. Najprije će se ispitati problem multikolinearnosti spomenut u prethodnom dijelu rada jer je to prvenstveno problem uzorka. Naime, multikolinearnost često se javlja u regresijskim modelima, i to zbog nedovoljnog broja (dostupnih) podataka.

U Tablici 6 može se iščitati VIF pokazatelj, koji iznosi 1,0225, što je manje od 5. Stoga se prema ovome pokazatelju može zaključiti da u modelu ne postoji problem multikolinearnosti.

Tablica 7.

Multikolinearnost

Broj svojstvene vrijednosti	Svojstvena vrijednost	CI	Proporcija varijance		
			Konstantni član	NPUO	Imovina
1	2.7301	1.0000	0.0009	0.0394	0.0009
2	0.2662	3.2028	0.0043	0.9518	0.0039
3	0.0037	27.2582	0.9948	0.0088	0.9952

Izvor: Izrada autora u programu SAS.

Kondicijski indeks CI kao mjera osjetljivosti procjena na male promjene u podacima ukazuje na mogući problem multikolinearnosti jer je pri nezavisnoj varijabli imovina $CI > 15$. Postoji još jedan način kojim se može ispitati problem multikolinearnosti, a to je analiza korelacijske matrice koja je prikazana u Tablici

5. Naime, elementi matrice regresorskih varijabli izvan dijagonale nemaju velike vrijednosti, što ne ukazuje na problem multikolinearnosti. Budući da postoji više načina kojima se može ispitati problem multikolinearnosti, važno je to učiniti s pomoću više pokazatelja jer kondicijski indeks CI ukazuje na mogući problem multikolinearnosti, dok pokazatelj VIF te analiza korelacijske matrice s niskim vrijednostima ne ukazuju na problem multikolinearnosti.

Drugi problem koji se može javiti u modelu višestruke linearne regresije jest problem autokorelacije grešaka relacije. Durbin–Watsonovim testom ispituje se pretpostavka da su uzastopni članovi grešaka relacije korelirani, to jest da postoji autokorelacija grešaka relacije prvog reda.

Tablica 8.

Durbin–Watsonov test

	DW	Pr < DW	Pr > DW
1	1.8493	0.2785	0.7215
2	2.0022	0.5626	0.4374
3	2.0273	0.6658	0.3342
4	1.9913	0.6749	0.3251

Izvor: Izrada autora u programu SAS.

U ovome radu testirala se autokorelacija prvoga reda. Razina značajnosti α je 5%, a kritične vrijednosti za $n = 47$, $k = 2$ dane su tablično te iznose $d_L = 1,430$ i $d_U = 1,615$. Testna veličina DW iznosi 1,8493, što je manje od dva te se stoga provodi jednosmjerni test o pozitivnoj autokorelaciji. Testna veličina uspoređuje se s kritičnom vrijednosti d_U . Budući da je $DW > d_U$, nulta hipoteza ne može se odbaciti te se zaključuje da nema autokorelacije grešaka relacije prvog reda.

5. ZAKLJUČAK

Osnovni je cilj ovoga rada bio ispitati utjecaj novčanog toka na zaduženost izabranih poduzeća u Republici Hrvatskoj s obzirom da je najveći broj prethodnih istraživanja provedenih na uzorku poduzeća izvan Republike Hrvatske. Većina dosadašnjih istraživanja provedena su s ciljem ispitivanja utjecaja dobiti na zaduženost. Budući da neto dobit predstavlja obračunsku osnovu, u ovome radu koristio se pokazatelj na temelju izvještaja o novčanim tokovima kako bi se ispitao utjecaj na zaduženost poduzeća.

Rezultati provedenog empirijskog istraživanja ukazuju na negativan utjecaj novčanog toka na zaduženost, što potvrđuje teoriju redoslijeda pakiranja, kao i prethodna relevantna istraživanja o ovoj temi. S obzirom na visok koeficijent linearne korelacije, može se zaključiti da između novčanog toka i zaduženosti postoji statistička negativna veza. Nadalje, rezultati ukazuju na

pozitivan utjecaj veličine poduzeća na zaduženost, što, pak, znači da postoji statistički značajna razlika u zaduženosti poduzeća, ovisno o veličini poduzeća.

Rezultati ovoga istraživanja mogu koristiti ekonomskim stručnjacima i analitičarima prilikom donošenja ocjene i preporuke o poslovanju poduzeća u smislu učinka novčanog toka na zaduženost poduzeća. Također, dobiveni rezultati mogu poslužiti menadžerima pri donošenju odluke o zaduživanju poduzeća jer provedeno empirijsko istraživanje nameće zaključak o postojanju jake negativne veze između novčanog toka i zaduženosti.

Kao ograničenje ovoga rada može se navesti malen broj nezavisnih varijabli izabranih u modelu jer postoji još niz čimbenika koji mogu utjecati na zaduženost poduzeća. Također, u daljnjim istraživanjima trebalo bi uzeti u obzir duže vremensko razdoblje, kao i usporediti utjecaj novčanog toka na zaduženost s poduzećima iz regije.

LITERATURA

Alnawaiseh, M. A. L. I, Alomari, R. M., Al-Rawashdeh, F., Alnawaiseh, M. B. (2017). „The effect of Free Cash Flow on the Companies' Financial Policies: Evidence from Jordan. *International Journal of Economic Research*, Vol. 14, No. 9, pp 1-9.

Ando, K., Matsumoto, K., Matsumoto, Y. (2017). „Business Performance of Firms Using Debt“. *Public Policy Review*, Vol. 13, No. 2, pp. 167-182.

Bahovec, V., Dumičić, K., Erjavec, N., Čizmešija, M., Kurnoga, N., Amerić, J., Čeh Časni, A., Jakšić, S., Sorić, P., Žmuk, B., Palić, I., Lolić, I. (2015). *Statistika*. Zagreb: Element.

Booth, L., Aivazian, V., Demirguc-Kunt, A., Maksimović, V. (2001). „Capital Structures in Developing Countries“. *The Journal of Finance*, Vol. 56, No. 1, pp. 87-130.

Buse, L., Ganea, M., Cîrciumaru, D. (2010). „Using Linear Regression In The Analysis Of Financial-Economic Performances“. *Annals of the University of Craiova – Economic Sciences Series*, Vol. 2, No. 38, pp. 1-12.

Dumičić, K., Bahovec, V., Čizmešija, M., Kurnoga, N., Čeh Časni, A., Jakšić, S., Palić, I., Sorić, P., Žmuk, B. (2011). *Poslovna statistika*. Zagreb: Element.

FINA, Registar godišnjih financijskih izvješća. <http://rgfi.fina.hr/JavnaObjava-web/izbornik.do>

Giacomino, D. E., Mielke, D. E. (1993). „Cash Flows: Another Approach to Ratio Analysis“. *Journal of Accountancy*, Vol. 175, No. 3.

Gulin, D., Perčević, H. (2013). *Financijsko računovodstvo – izabrane teme*. Zagreb: Hrvatska zajednica računovođa i financijskih djelatnika.

Gurtani, M. M., Mehr, A. A. (2015). „Assessment of The relation between systematic risk and debt to cash flow ratio“. *International Journal of Engineering Research And Management (IJERM)*, Vol. 2, No. 4, pp. 57-67.

Hall, G. C., Hutchinson, P. J., Michaelas, N. (2004). „Determinants of the Capital Structures of European SMEs“. *Journal of Business Finance & Accounting*, Vol. 31, No. 5-6, pp. 711-728.

Hladika, M., Valenta, I., Milčić, I. (2018). „Analiza međuovisnosti između novčanog toka i zaduženosti u hotelskoj industriji u Republici Hrvatskoj“. U: *Zbornik radova Ekonomskog fakulteta Sveučilišta u Mostaru*, Vol. 24, pp. 195-207.

Matemilola, B. T., Ahmad, R., Kareem, S. D., Mautin, O. D., Sakiru, O. K. (2015). „Dynamic Relationship between Debt and Cash flow in Pecking Order Theory: Evidence from Panel GMM“. *Journal of Marketing and Consumer Research*, Vol. 6, pp. 30-38.

Matemilola, B. T., Nassir, A. M., Bany-Arifin, A. N. (2014). „Debt and Cash flow Relationship in Pecking Order Evidence Theory of Corporate Financing: Dynamic Panel Evidence“. *The Empirical Economic Letters*, Vol. 13, No. 6, pp. 618-623.

Myers S. C., Majluf, N. S. (1984). „Corporate financing and investment decisions when firms have information that investors do not have“. *Journal of Financial Economics*, Vol. 13, No. 2, pp. 187-221.

Rezaei, M., Jafari, S. M. (2015). „Identifying the Relationship between Financial Leverage and Cash Flows of the Companies Listed in Tehran Stock Exchange“. *Indian Journal of Science and Technology*, Vol. 8, No. 27, pp. 1-13.

Tong, G., Green, C. J. (2005). „Pecking Order or Trade-off Hypothesis? Evidence on the Capital Structure of Chinese Companies“. *Applied Economics*, Vol. 37, No. 19, pp. 2179-2189.

Zagrebačka burza. <https://www.zse.hr/default.aspx?id=36769>

Anita Čeh Časni, PhD

Assistant Professor
Faculty of Economics and Business, Zagreb
Department of Statistics
E-mail: aceh@efzg.hr

Josipa Filić, mag. oec.

Teaching Assistant
Faculty of Economics and Business, Zagreb
Department of Statistics
E-mail: jfilić@net.efzg.hr

MODELLING THE INFLUENCE OF CASH FLOW ON INDEBTEDNESS OF CROATIAN COMPANIES USING LINEAR REGRESSION MODEL

Abstract

The aim of this paper is to examine the statistical relationship between cash flow and corporate debt using multiple linear regression model. In addition to cash flow, the size of the enterprise was used as an additional explanatory variable in the model. Since there is a great deal of research in the relevant literature on the relationship between profit and debt, this paper uses cash flow instead of profit, which is a contribution to the existing literature. The results of the regression analysis indicate a negative impact of cash flow on indebtedness, which also confirms pecking order theory. In addition, the results show a positive (albeit weaker) impact of corporate size on debt.

Keywords: multiple linear regression model, cash flow, indebtedness, firm size

JEL classification: C30, G30, G32, L25